

인공지능을 이용한 공학시스템 상태진단 및 예지

윤 병 동	서울대학교 기계항공공학부 부교수	e-mail : bdyoun@snu.ac.kr
황 태 완	서울대학교 기계항공공학부 박사과정	e-mail : michel4546@snu.ac.kr
조 수 호	서울대학교 기계항공공학부 석사과정	e-mail : jsh1201@snu.ac.kr
이 동 기	서울대학교 기계항공공학부 석사과정	e-mail : kidesper1@naver.com
나 규 민	서울대학교 기계항공공학부 석사과정	e-mail : jeonryu@naver.com

이 글에서는 인공지능을 이용한 공학시스템 고장진단 및 예지기술(PHM: Prognostics and Health Management)의 개념을 소개하고, 실제 적용 사례를 제시한다.

산업현장의 설비들은 수많은 물리적 구성품이 복잡적으로 묶여져 있는 하나의 시스템이다. 따라서 한 부품의 불시 고장은 전체적인 시스템의 성능 저하 및 엄청난 인적, 물적, 사회적 손실을 초래할 수 있다. 향후 산업설비의 용량 및 복잡도가 증가할 것을 고려하면 신뢰성 있는 시스템 관리는 중요한 문제이다. 이에 대한 대안으로, 센서를 이용해 산업설비의 상태를 모니터링하여 고장을 진단하고 잔여유효수명을 예측하는 시스템 고장진단 및 예지기술(Prognostic and Health Management, 이하 PHM)이 주목을 받고 있다.

PHM기술은 그림 1과 같이 ① 데이터 취득(Sensing), ② 전처리 및 특징인자 추출(Reasoning), ③ 고장 진단(Diagnostics), ④ 수명 예측(Prognostics)으로 진행된다.

① 데이터 취득 단계에서는 실제 산업설비의 특성을 분석하고 이상 상태를 감지하기 위한 최적의 센서 종류, 위치, 수량을 결정하고 데이터 취득 시스템을 구축한다. ② 전처리 및 특징인자 추출 단계에서는 계속, 수집된 원신호에서 고장과 관련 있는 통계적, 물리적 건전성 특징인자를 추출한다. ③ 고장 진단 단계에서는

추출한 건전성 특징인자를 바탕으로 정상/이상을 판단하고 고장 모드를 추정한다. ④ 수명 예측 단계에서는 실제로 시스템이 정지에 이르기까지 남은 잔여 유효수명을 예측한다. 하지만 특정 시스템에 PHM기술을 적용하기 위해서는 시스템에 대한 물리적 지식, 다차원 특징인자 분석, 수많은 고장 데이터가 요구된다.

최근에는 인공지능(Artificial Intelligence) 기술을 활용하여 이러한 문제점을 극복하려는 연구가 활발히 진행되고 있다. 인공지능이란 '인간의 학습능력과 추론능력, 지각능력 등을 컴퓨터 프로그램으로 실현한 기술'을 의미하며 특히 기계학습(machine learning) 기술을 활용하여 현실화되고 있다. 기계학습기술을 활용하면 다차원의 방대한 데이터를 학습하여 새로운 데이터의 속성을 분류하고 예측할 수 있다. 기계학습 기술을 PHM에 접목하면, 다차원의 건전성 특징인자를 바탕으로 자동화된 고장 분류 수행 및 고장 기준 선정 및 열화 모델 구축을 수행할 수 있다. 또한 딥러닝(deep learning) 기술을 활용하여 시스템에 대한 적은 물리적 이해를 바탕으로도 건전성 특징인자를 추출하는 연구도 진행되고 있다. 이러한 기계학습을 구현하

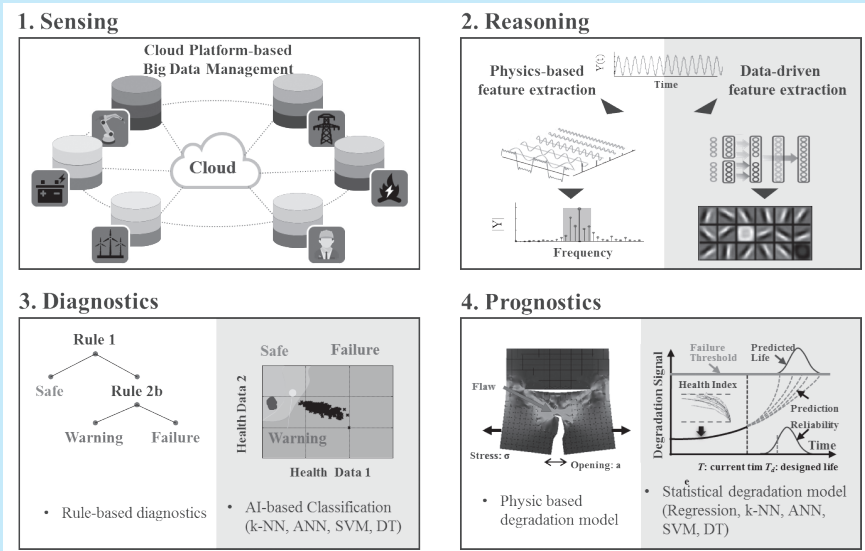


그림 1 기존 PHM기술(흰색 배경)과 인공지능을 활용한 PHM기술(파란색 배경) 흐름도

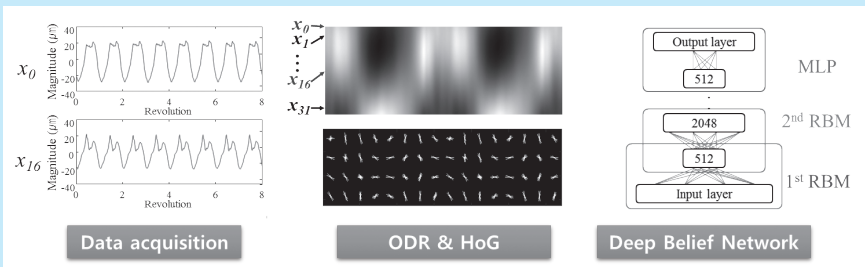


그림 2 딥러닝을 활용한 자율 특징인자 추출 방법

기 위해서 인공신경망(Artificial neural network), kNN(k Nearest Neighbor), 서포트 벡터 머신(Support vector machine), 의사결정 트리(Decision tree) 등이 활용된다. 아래 각 섹션에는 인공지능을 활용한 PHM 사례를 소개하고 인공지능을 활용하기 위한 주의 점을 정리하고자 한다. 자세한 연구사례는 <http://shrm.snu.ac.kr>에서 확인할 수 있다.

사례 1. 딥러닝을 활용한 저널베어링 고장진단

딥러닝이란 신경망 기반의 비선형 변환 기법을 활용하여 다차원의 데이터를 추상화하고 이 과정에서 핵심적인 정보를 추출하는 기계학습의 한 기법이다. 기존에는 사람이 정의한 특징인자를 데이터로부터 추출하

여 분류 및 예측 문제를 해결하였다. 하지만 딥러닝을 활용하면 학습 데이터로부터 자율적으로 특징인자를 추출하고, 이를 바탕으로 분류 및 예측 문제를 해결할 수 있다. PHM에 딥러닝을 적용한다면 특징인자 추출 단계를 고도화할 수 있다.

Oh(2016)는 딥러닝 기술을 활용하여 저널베어링 고장진단에 사용되는 특징인자를 추출하고 고장진단을 수행하였다. 그림 2처럼 진동 데이터를 딥러닝에 입력하기 위해 ODR(O m n i Directional Regeneration) 기법을 활용하여 진동 신호를 이미지화 하였으며, HoG(Histogram of Gradient) 기법으로 전처리를 수행하였다. 그 후 특징인자를 추출하기 위해 다층의 제한된 볼츠만 머신(Restricted Boltzmann Machine)을 활용하여 깊은 신경

망(Deep Belief Network)을 구현하고 건전성 특징인자를 추출하였다. 최종적으로 특징인자를 바탕으로 다층 퍼셉트론(Multi Layer Perceptron)에 학습하여 다양한 고장모드를 학습하고 평가하였다. 그 결과 딥러닝을 통해 추출된 건전성 특징인자의 고장진단 정확도가 전문가 지식에 기반해 추출한 건전성 특징인자에 비해 높음이 확인되었다.

사례 2. 상호학습을 활용한 베어링 수명예측

상호학습(Co-training)기법은 고장 발생 전의 열화 데이터인 중지 데이터(suspension data)를 활용하여 잔여 유효수명 예측의 정확성을 높이는 방법이다. 기계학습 기반의 PHM을 수행하기 위해서는 고장

까지의 열화 데이터가 필요하지만 실제 공학 시스템에서는 고장 데이터를 확보하기가 어렵다. 상호학습기법은 이러한 어려움을 효과적으로 해결하면서 예측의 강건성도 확보할 수 있는 장점이 있다. 상호 학습 개념은 그림 3과 같다. 라벨링 (labeling)이 된 학습 데이터를 활용하여 각각의 기계학습 알고리즘에 적용을 한 뒤, 중지 데이터를 라벨링시킨다. 그 후, 라벨링된 중지 데이터를 활용하여 다른 기계학습 알고리즘을 학습하여 학습량을 늘린다.

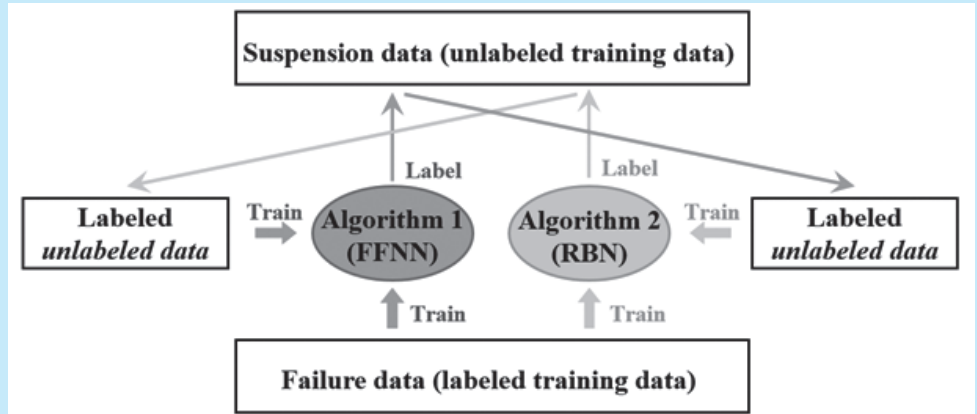


그림 3 상호학습 잔여수명 예측 기법

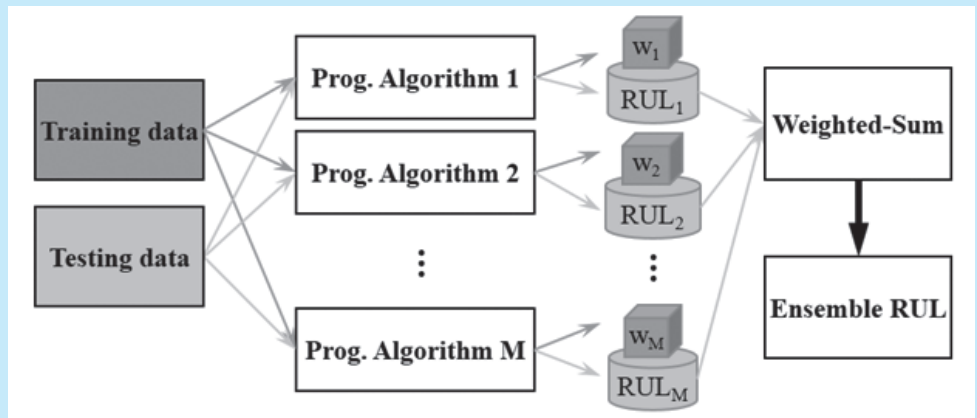


그림 4 앙상블(Ensemble) 잔여수명 예측 기법

Chao Hu(2015)는 상호학습(Co-training)기법을 활용해 팬 베어링의 잔여수명을 예측하였다. 팬 베어링에 불평형 질량을 인가하여 불균형상태로 만든 뒤 가속수명시험을 수행하였고, 이 과정에서 진동 신호를 획득하였다. 획득한 32개 베어링의 열화 신호를 10개의 고장 데이터, 10개의 중지 데이터, 12개의 검증 데이터로 분류하였다. 알고리즘은 신경망 기반의 기계학습 기법인 FFNN(Feedforward neural network)과 RBN(Radial basis Network)을 활용하였다. 단일 알고리즘을 활용하는 경우 10개의 고장 데이터만을 학습하는 반면, 상호학습 기법을 활용한 경우 10개의 고장 데이터와 10개의 중지 데이터를 모두 활용하여 학습할 수 있다. 결과적으로 상호학습 기법을 활용하

면 단일 알고리즘에 비해 잔여수명 예측 오차가 감소하는 것을 확인할 수 있다.

사례3. 앙상블기법을 활용한 제트엔진 수명 예측
앙상블(ensemble)기법은 다양한 예지 알고리즘을 종합적으로 고려하여 잔여수명을 예측하는 기법이다. 일반적으로 기계학습 알고리즘을 활용할 때 가장 좋은 성능을 가지는 알고리즘을 선택하게 되고 선택되지 않은 알고리즘을 구성하는 비용이 낭비된다. 앙상블기법은 이러한 낭비를 줄일 수 있을 뿐만 아니라 더 높은 예지 정확성을 얻을 수 있는 장점이 있다. 앙상블기법의 개념은 그림 4와 같다. 학습 데이터 (training data)를 이용하여 다양한 예지 알고리즘들

의 가중치를 결정하고 평가 데이터(test data)를 대입해 각 알고리즘의 잔여수명 예측치를 구한다. 최종적으로 각각의 잔여수명에 가중치 평균을 통해 잔여수명을 예측한다.

Chao Hu(2012)는 앙상블기법을 활용해 2008년 IEEE Data Challenge의 제트엔진 수명 예측 문제를 연구하였다. 제트엔진 시뮬레이션을 6가지 다른 운행 조건에서 수행하여 21종의 센서에서 열화 데이터를 얻었다. 앙상블예지기법을 사용했을 때 개별 알고리즘보다 수명 예측의 정확도가 높음을 확인할 수 있다. 또한 앙상블 알고리즘을 활용하면 새로 개발될 예지 알고리즘을 통합할 수 있는 장점이 있다.

맺음말

이 글에서는 기존의 전문가 지식 기반 PHM기술의 한계점에서 벗어나 인공지능에 기반한 PHM기술을 딥러닝, 상호학습, 앙상블과 같은 사례를 통해 확인하였다. 해가 거듭될수록 기계시스템은 더욱이 복잡해지고 기술 분야 또한 세분화되고 있으며, IoT(Internet of Things) 기술의 확산으로 방대한 데이터를 취득하고 있기 때문에 인공지능에 기반한 PHM기술은 현대 공학시스템 관리 분야에서 핵심적인 요소로 대두될 것이다. 실제로 산업인터넷 플랫폼계의 선두주자인 GE(General Electric)는 Predix라는 제품의 핵심 역할을 확보하기 위해 인공지능 기반의 스타트업들을 다수 인수한 것으로 보도되었다. 인공지능기술을 활용하여 PHM기술을 개발하는 경우 특징인자를 자동적으로 추출할 수 있고, 다차원 데이터를 분석할 수 있다는 장점이 있다. 하지만 물리적 지식 없이 고장 진단 및 예측 모델을 만들기 위해서는 수많은 데이터가 필요하고, 데이터를 처리하는 데 많은 시간이 걸린다는 문제가 있다. 따라서 향후에는 기계공학적 전문가 지식과 인공지능을 결합한 PHM기술을 개발함으로써 그 효용성을 증가시킬 것으로 기대된다.

참고문헌

Oh, Hyunseok, et al. "Smart diagnosis of journal bearing rotor systems: Unsupervised feature extraction scheme by deep learning." (2016).

Jeon, Byung Chul, et al. "Datum unit optimization for robustness of a journal bearing diagnosis system." *International Journal of Precision Engineering and Manufacturing*16.11 (2015): 2411-2425.

Jung, Joon Ha, et al. "Omnidirectional regeneration (ODR) of proximity sensor signals for robust diagnosis of journal bearing systems." *Mechanical Systems and Signal Processing*90 (2017): 189-207.

Hu, Chao, et al. "A co-training-based approach for prediction of remaining useful life utilizing both failure and suspension data." *Mechanical Systems and Signal Processing*62 (2015): 75-90.

Hu, Chao, et al. "Ensemble of data-driven prognostic algorithms for robust prediction of remaining useful life." *Reliability Engineering & System Safety*103 (2012): 120-135.

Wang, Pingfeng, Byeng D. Youn, and Chao Hu. "A generic probabilistic framework for structural health prognostics and uncertainty management." *Mechanical Systems and Signal Processing*28 (2012): 622-637.

윤병동. "에너지산업 분야에의 고장진단 및 예지기술 적용 사례." *기계저널*, 53.7 (2013): 44-52.

이수학, and 윤병동. "Industry 4.0 과 고장예지 및 건전성관리 기술 (PHM) 의 방향." *소음·진동* 25.1 (2015)

오현석, and 윤병동. "데이터 특성인자 추출을 위한 PHM기술 연구 동향." *기계저널*56.11 (2016): 32-36.